



# Formando un lazo con su nuevo compañero

El rol que el aprendizaje de máquina tiene en el análisis cuantitativo de datos

# Acerca del Deloitte Center for Integrated Research

El Center for Integrated Research, de Deloitte, se centra en desarrollar perspectivas frescas sobre problemas de negocio críticos que cortan a través de industrias y funciones, desde el cambio rápido de las tecnologías emergentes hasta el factor consistente del comportamiento humano. Nosotros miramos temas transformadores de maneras nuevas, entregando pensamiento en una variedad de formatos, tales como artículos de investigación, videos cortos, talleres presenciales, y cursos en línea.

## Conéctese

Para conocer más acerca de la visión del Center for Integrated Research, sus soluciones, el liderazgo del pensamiento, y eventos por favor visite [www.deloitte.com/us/cir](http://www.deloitte.com/us/cir).

### HUMAN CAPITAL

Los profesionales de Human Capital, de Deloitte, aprovechan investigación, analíticas, y perspectivas de industria para ayudar a diseñar y ejecutar los programas de Recursos Humanos, talento, liderazgo, organización, y cambio que permitan el desempeño del negocio mediante el desempeño de las personas. [Conozca más.](#)

# Contenidos

Análisis de la investigación cualitativa: ¿Hay una mejor manera?	2
Disección del proceso: visualización, clasificación, y detección	4
De las perspectivas a la acción: sugerir, suponer, y dirigir	11
Implicaciones prácticas	12
Notas finales	14

# Análisis de la investigación cualitativa: ¿Hay una mejor manera?

LA MAYORÍA DE LAS ORGANIZACIONES usa una variedad de métodos de recolección y análisis de datos para entender a sus *stakeholders*, ya sea a través de encuestas de satisfacción del cliente, revisiones de producto, o encuestas del pulso del empleado. Esas maneras de obtener perspectivas caen en dos categorías amplias: recolección y análisis de datos cuantitativo y cualitativo. Las respuestas cuantitativas pueden ser contadas y analizadas rápida, eficiente, y exactamente con la ayuda de fórmulas matemáticas lógicas, algoritmos, y, ahora, máquinas. Analizar datos cualitativos típicamente es más complicado, y ampliamente permanece en la provincia de los analistas humanos, dado que requiere un alto grado de entendimiento contextual e inteligencia social.

Para que las perspectivas de análisis cualitativo sean consideradas válidas – y tomadas en serio – el método de la vieja escuela generalmente involucra dos o más personas que analicen por separado (por ejemplo, codificando o categorizando) los datos recaudados. Sus resultados son entonces comparados y sintetizados. Si bien este proceso ayuda a validar los hallazgos mediante limitar el sesgo y la subjetividad humanos, también hace que esos tipos de estudios sean mucho más intensivos en recursos.

## ¿Pueden las máquinas ser la respuesta?

Dada la creciente sofisticación de la inteligencia artificial y de los algoritmos de máquina disponibles para posiblemente ayudar con el análisis tanto cuantitativo como cualitativo, parece solo lógico – y prudente – que los líderes de la empresa exploren cómo pueden capitalizar e incorporar la tecnología ya sea para reemplazar o para aumentar los procesos actuales. Usar máquinas para analizar datos cualitativos podría arrojar eficiencias de tiempo y costo, así como también mejorar el valor de las perspectivas derivadas de los datos.

Para entender la extensión en la cual la tecnología puede ser usada para realizar análisis cuantitativo de datos, hemos comparado un equipo de tres analistas con una máquina (o, más aún, un algoritmo de máquina diseñado específicamente para análisis de datos) en el análisis de los datos cualitativos que hemos obtenido en una reciente encuesta que realizó Deloitte.<sup>1</sup> Este artículo usa los hallazgos provenientes de este “hornear,” así como también investigación y literatura existente sobre la inteligencia humano-máquina y colectiva, para entender qué valor los humanos y las máquinas pueden proporcionar en cada paso del análisis cualitativo. Elaborando a partir de la investigación existente sobre capacidades humanas, recomendamos maneras para potencialmente integrar máquinas en el proceso de análisis de investigación cualitativa e identificar cómo las contribuciones de los humanos pueden guiar a los líderes del negocio para obtener perspectivas procesables a partir de la investigación cualitativa.<sup>2</sup>

FIGURA 1

## LAS MÁQUINAS PUEDEN ASUMIR VARIOS ROLES CUANDO TRABAJAN CON HUMANOS



Fuente: Basado en Jim Guszczka y Jeff Schwartz, "Supermind: How humans and machines can work together," Deloitte Review 24, January 28, 2019; Thomas W. Malone, Superminds: The Surprising Power of People and Computers Thinking Together (Boston: Little, Brown and Company, 2018).

### METODOLOGÍA DEL ESTUDIO

La encuesta European Workforce, de Deloitte, reunió más de 15,000 personas de 10 países europeos para entender las expectativas de la fuerza laboral (lea un análisis detallado de los resultados en Voice of the workforce in Europe).<sup>3</sup> Para el reporte actual, nos centramos en analizar la pregunta cualitativa: "Por favor proporciónenos cualesquiera comentarios adicionales que usted sienta estén relevantemente vinculados con *qué le mantiene a usted motivado en el lugar de trabajo y/o qué considera usted se necesita cambiar para avanzar.*" Un equipo en-casa de tres analistas y un algoritmo administrado por un equipo de ciencia de datos analizó las respuestas en inglés de texto libre. Luego de limpiar los datos por las respuestas irrelevantes e inválidas, para este análisis consideramos 372 respuestas. Esas respuestas fueron categorizadas en temas relevantes para el análisis del sentimiento.

# Disección del proceso: visualización, clasificación, y detección

**P**ARA ANALIZAR Y GANAR perspectivas significativas provenientes de preguntas cualitativas (abiertas), la mayoría de los analistas generalmente siguen tres pasos principales: visualización de datos, clasificación (o categorización), y finalmente, detección (describir las emociones de quien responde).

## Paso uno: visualización (limpiar los holgazanes y los malos comportamientos)

El primer paso es más o menos lo que el nombre sugiere: visualizar los datos por respuestas ya sea ilegibles, sin sentido, o indescifrables, así como también las respuestas elegibles pero irrelevantes.

Si bien nuestro algoritmo fue más rápido en la visualización, llevando solo el 17 por ciento del tiempo de análisis que se necesitó para visualizar las respuestas no utilizables, la calidad del resultado del algoritmo fue inferior: falló en visualizar los datos a un nivel adecuado para el paso siguiente. Específicamente, mientras la visualización manual arrojó solo 35 por ciento de respuestas válidas, el algoritmo consideró que el 73 por ciento de las respuestas eran válidas. Si bien fue bueno para identificar respuestas indescifrables (tales como “\$%v&()” o “hoihoihoij”), la máquina no fue tan buena en la identificación de respuestas legibles que no agregan valor, tales como “sin comentarios adicionales,” “no aplica,” “no estoy seguro,” “no sé, no puedo pensar,” y “excelente encuesta.”

Entonces, mientras las máquinas pueden dar un primer buen paso, la vigilancia y revisión humanas todavía son necesarias en el paso de visualización. Las máquinas en su estado actual típicamente juegan el rol de las “herramientas” en el proceso de visualización.

**Si bien nuestro algoritmo fue más rápido en la visualización, llevando solo el 17 por ciento del tiempo de análisis que se necesitó para visualizar las respuestas no utilizables, la calidad del resultado del algoritmo fue inferior: falló en visualizar los datos a un nivel adecuado para el paso siguiente.**

## Paso dos: clasificar y sintetizar (dándole sentido a la locura)

El siguiente paso generalmente es clasificar o categorizar los datos en cubos o temas recurrentes para identificar las perspectivas clave y la retroalimentación de quienes responden. Esta parte del ejercicio fue particularmente desafiante, dado que la pregunta de la encuesta no solo era amplia sino también de “doble cañón,”<sup>4</sup> haciéndoles a quienes respondan dos preguntas diferentes a la vez. Específicamente, a quienes respondieron se les preguntó sus puntos de vista acerca de *qué les mantenía motivados en el lugar de trabajo y/o qué necesitaban cambiar para avanzar*. A causa de esto, los analistas humanos y el algoritmo no solo tenían que categorizar las respuestas, sino también discernir cuál aspecto – o aspectos – de la pregunta las personas estaban respondiendo. Los analistas y la máquina abordaron esta tarea usando estrategias completamente diferentes.

## NUBES DE PALABRAS: ÁMELAS U ÓDIELAS, USTED NO LAS DEBE IGNORAR

Desde que el mapa de los puntos de referencia en París, una de las primeras nubes de palabras, fue creado en 1976, las nubes de palabras se han vuelto crecientemente populares por su capacidad para proporcionar una instantánea rápida de los datos.<sup>5</sup> Algoritmos simples pueden rápidamente crear nubes de palabras con base en la frecuencia relativa de las palabras en un conjunto de datos. Sin embargo, antes de usar nubes de palabras para generación de perspectivas y toma de decisiones, es importante reconocer algunas de sus limitaciones clave.

FIGURA 2

### Beneficios y limitaciones de las nubes de palabras

#### ÁMELAS

- Las nubes de palabras típicamente son rápidas de crear, visualmente atractivas, y divertidas para compartir.
- Las nubes de palabras típicamente representan el primer paso en minería de textos, que ofrece nubes para análisis adicional.

#### ÓDIELAS

- Las nubes de palabras a menudo son creadas usando palabras individuales más que frases, por lo tanto, perdiendo el riesgo de pérdida de significado a través del contexto en el cual las palabras son usadas.
- Puede ser difícil identificar visualmente las palabras de frecuencia-más-baja en una nube de palabras en el orden correcto, dado que la diferencia en el tamaño de fuente se vuelve despreciable al final de la lista. Otros tipos de gráficos, tales como gráfico de barras sencillo, podría hacer mejor el trabajo.<sup>6</sup>
- Los algoritmos permiten que el usuario cree nubes de palabras en diversos estilos y formatos. Si bien esto puede incrementar el atractivo estético, la apariencia de las palabras (especialmente las más pequeñas) puede cambiar con el formato, lo cual podría llevar a interpretaciones engañosas basadas en el formato seleccionado.

Fuente: Análisis de Deloitte.

## LA TOMA DE LA MÁQUINA: UNA NUBE DE PALABRAS LE DICE A USTED TODO LO QUE USTED NECESITA CONOCER... ¿O LO HACE?

Nuestro algoritmo enfocó la tarea de clasificar de una manera similar a la estrategia seguida por la mayoría de productos de software cualitativo altamente considerados actualmente en el mercado. Tomó todas las frases cualitativas, identificó la frecuencia con la cual varias palabras eran mencionadas, y usó la información de la frecuencia para generar una nube de palabras: una descripción gráfica sucinta de las frecuencias de palabras, colocando las palabras más a menudo mencionadas en fuentes más grandes y sólidas en el centro de la gráfica y las palabras menos a menudo mencionadas en texto más pequeño en los extremos (figura 3), presentando por lo tanto una vista en miniatura de los hallazgos. La nube

de palabras resaltó los temas clave relevantes para el análisis: tecnología, trabajo, entrenamiento, y similares.

Para probar la capacidad del algoritmo para identificar qué conceptos caen en cada uno de esos temas, les pedimos que clasificaran los conceptos usando modelación de temas, arrojando las categorías que se muestran en la figura 4. La máquina no etiquetó esas categorías, pero simplemente las numeró arbitrariamente. En la inspección, las categorías generadas-por-la-máquina fueron difíciles de relacionar con un tema específico. Por ejemplo, si bien la categoría 5 parece estar asociada con compensación, también contiene unos pocos temas no-relacionados (tales como “tecnología” y “cambio”) que se ajustan estadística, pero no contextualmente. También, dado que la categorización de la máquina fue orientada por palabras, no por frases, es



es imposible estar seguro si la categorización que hizo el algoritmo tuvo en cuenta el significado comprensivo y exacto de quienes respondieron.

Como puede verse, la categorización generada-por-la-máquina no parece tener sentido, y por lo tanto necesita intervención manual para elaborar perspectivas significativas.

### LA TOMA HUMANA: PENSAMIENTO SINTÉTICO – DIVIDA, CATEGORICE (FRASES), LUEGO COMPARE

La misma tarea de categorización fue realizada luego por nuestros analistas humanos. La clasificación y síntesis de datos no-estructurados típicamente requiere tanto tiempo como esfuerzo cognitivo, involucrando concentración, atención, intuición, y pensamiento sintético e integrador. Mientras que la máquina solamente contó la frecuencia de las palabras mencionadas, los analistas atravesaron las respuestas, las clasificaron en lo que intuitivamente percibían eran los temas recurrentes comunes, y crearon etiquetas para las categorías (figura 5).

Con base en el análisis humano, un 40 por ciento de las respuestas tuvo que ver con el empleo, el trabajo, o la satisfacción en el trabajo de quien respondió. Las respuestas muestras en esta categoría incluyeron, “Disfruto mi trabajo y lo que hago; esto es suficiente motivación” y “Amo el trabajo que estoy haciendo.” Las siguientes tres categorías más populares representa cada una el 10-15 por ciento de las respuestas abiertas analizadas, fueron compensación, tecnología, y entrenamiento/mejora. En seguida estuvo liderazgo/administración, representando casi el 7 por ciento de las respuestas.

## Paso tres: Detectar (moverse desde declaraciones hacia sentimientos)

Mientras clasificar y sintetizar se refiere a entender lo que los trabajadores están *diciendo*, detectar (también conocido como análisis del sentimiento) es acerca de entender lo que las personas están *sintiendo*. Es importante conocer, por ejemplo, si las personas sienten positiva o negativamente acerca de los temas que mencionan. Por otra parte,

FIGURA 5

## La clasificación manual (humana) arrojó categorías lógicas para la motivación en el lugar de trabajo

Número de respuestas



Fuente: Análisis de Deloitte.

en el caso de nuestra pregunta de dos partes, ni las categorías de humano ni las de la máquina señalaron a cuál parte de la pregunta (“qué lo mantiene a usted motivado” o “qué necesita cambiar”) quienes respondieron se estaban refiriendo. La meta del siguiente paso, detección, era descifrar las emociones, intereses, o preocupaciones subyacentes de quienes respondieron, así como también a cuál(es) parte(s) de la pregunta de dos partes quienes respondieron habían respondido. Armados con esta información, los analistas podrían comenzar una conversación con los líderes del negocio acerca de qué perspectivas los datos ayudaron a identificar.<sup>7</sup>

Mientras clasificar y sintetizar se refiere a entender lo que los trabajadores están diciendo, detectar (también conocido como análisis del sentimiento) es acerca de entender lo que las personas están *sintiendo*.

### LA TOMA DE LA MÁQUINA: MORE LAS FRASES, PERO ÁNCLESE EN LAS PALABRAS

En nuestro estudio, los analistas humanos y el algoritmo trabajaron primero en el análisis del sentimiento – clasificando cada respuesta ya sea como principalmente positiva o principalmente negativa.<sup>8</sup>

Nosotros instruimos al algoritmo para que considerara las frases asociadas con las categorías creadas-por-el-humano y les asignara un valor positivo o negativo. Si bien el algoritmo una vez más fue más rápido, completando la tarea en un quinto del tiempo que le llevó a los humanos, en algunos casos se equivocó en marcar. Por ejemplo, clasificó “Me siento extremadamente motivado” como un sentimiento negativo. El examen del software de la máquina reveló que esto se debió a su paquete de datos del diccionario, el cual había asignado un valor negativo a la palabra “extremadamente.”

Una vez más, el desafío para la máquina fue digerir una frase en su totalidad – esto es, intuir el significado contextual, en oposición a las definiciones de las palabras individuales.

Centrarse en las solas palabras para identificar emociones, como todos sabemos, no siempre es confiable. Imagine, por ejemplo, un administrador usando una máquina para interpretar una frase como “Sería terrible perder a Mary como colega.” Centrándose en solo las palabras, la máquina probablemente clasificaría esta retroalimentación como negativa, dado el uso de la palabra “terrible.”

Nuestro algoritmo no solo hizo un trabajo pobre de asignar emociones a las frases, sino que tampoco proporcionó valor al burlarse de respuestas que pertenecían a “qué le mantiene a usted motivado” y cuál a “qué necesita cambiar.”

### LA TOMA DEL HUMANO: SEPRE LAS RESPUESTAS E IDENTIFIQUE EMOCIONES CON BASE EN EL CONTEXTO

Para realizar el análisis del sentimiento, nuestros analistas humanos primero asignaron una valencia – positiva o negativa – a cada frase (no palabra) con base en la emoción dominante subyacente de cada una de las respuestas (figura 6).<sup>9</sup> Tales etiquetas

FIGURA 6

### Los analistas humanos pudieron identificar si quienes respondieron sentían positiva o negativamente acerca de un tema



Fuente: Análisis de Deloitte.

son invaluable para quienes toman decisiones de empresa tales como comercializadores y reclutadores, particularmente cuando se trata de medir lo atractivo de un producto, servicio, o posición de trabajo.

Los analistas abordaron luego separar cuáles frases eran relevantes para “qué le mantiene motivado” y las relevantes para “qué necesita cambiar.” En la vida real, quizás esta sería la información más importante para que líderes y administradores actúan a partir de ella.

Después de la satisfacción general del trabajo, la compensación fue el tema más importante para quienes respondieron, de manera que los analistas ordenaron todas las frases relacionadas con compensación con las relacionadas con “me mantiene motivado” y las relacionadas con “necesita cambiar.” Este análisis mostró que quienes respondieron identificaron al dinero como su principal motivador – específicamente, incentivos monetarios y no-monetarios y su capacidad para pagar sus factoras. En términos de lo que “se necesita cambiar,” quienes

respondieron fue más probable que citaran un incremento en el pago general y los incentivos monetarios. El entorno de trabajo y el número de horas de trabajo en línea con la compensación ofrecida también fueron factores importantes sugeridos para el cambio.

Como es evidente de nuestra comparación de los humanos con el algoritmo, las máquinas están limitadas en su capacidad para realizar un análisis completo y exacto del sentimiento. Los sentimientos son matizados, y las máquinas encuentran difícil leerlos adecuadamente por varias razones: el uso de un diccionario rígido de datos, lectura de palabras y no de frases, y la necesidad de analizar el sentimiento en sub-categorías para las preguntas de doble cañón. Estas son limitaciones serias que los investigadores deben considerar cuando se apoyen en el análisis algorítmico. Los humanos tienen un rol clave a jugar en este paso final para asegurar que las perspectivas correctas orienta la toma de decisiones.

**Los sentimientos son matizados, y las máquinas encuentran difícil leerlos adecuadamente por varias razones: el uso de un diccionario rígido de datos, lectura de palabras y no de frases, y la necesidad de analizar el sentimiento en sub-categorías para las preguntas de doble cañón.**

# De las perspectivas a la acción: sugerir, suponer, y dirigir

**H**ASTA AHORA, NUESTRO “hornear” máquina-humano ha demostrado el importante rol que los humanos juegan en el análisis de datos y qué calor ofrecen a la actividad. Cada paso del camino – en visualizar, clasificar, y detectar – hay la necesidad no solo de involucramiento humano sino también del saber-cómo del humano para asegurar la exactitud y la completitud del análisis. Y el trabajo del humano típicamente no termina allí. El punto completo del análisis de datos es proporcionar no solo perspectivas, sino también recomendaciones que se puedan llevar a la acción – de las cuales nuestro algoritmo mostró solo capacidad limitada para hacer. Además, la investigación y el recaudo de

perspectivas típicamente no son actividades de una vez sino componentes de un esfuerzo o portafolio continuo más grande. Los analistas humanos, con su conocimiento profundo de los datos, pueden ayudar a orientar la agenda de investigación de la compañía y tamizar y priorizar los diferentes planes de implementación, las comunicaciones, y las recomendaciones de la estrategia de investigación. Un equipo ideal de investigación humano-máquina orienta el proceso mediante sugerir cuáles conjuntos de datos son utilizables y significativos, avanza para suponer consideraciones con base en el entendimiento contextual, para finalmente dirigir acciones informadas para satisfacer los objetivos de negocio claves.

# Implicaciones prácticas

CONSIDERANDO LAS CAPACIDADES de humanos y máquinas, detalladas arriba, a continuación, están algunos pensamientos para que los líderes los consideren cuando determinen cómo enfocar el análisis de datos cualitativos:

- **El contexto es el rey.** Cuando se trata de nubes de palabras, lo que la máquina conoce no es igual. Pero si bien son útiles para mensajería y para obtener un entendimiento general de lo que está en las mentes de los *stakeholders*, las máquinas se desempeñan pobremente en leer entre líneas, entender matices, y tener en cuenta las condiciones que rodean una declaración. Es decir, no todas las máquinas son iguales – y todavía están aprendiendo y evolucionando. Nosotros anticipamos que, con aprendizaje de máquina, los diccionarios cambiarán y mejorarán con el tiempo, como también lo podría hacer el lenguaje humano. Las capacidades humanas deben continuar siendo necesarias para mantener las cosas en contexto.
- **La única constante es el cambio - con el cambio viene la imprevisibilidad.** Es difícil visualizar un instrumento de búsqueda que contenga preguntas redactadas no sub-óptimamente debido a error humano, la necesidad de incluir preguntas heredadas, o una pregunta de último minuto que haga un *stakeholder*. Por lo tanto, los investigadores – como un fontanero que se trepa por un fregadero por primera o centésima vez – nunca saben exactamente qué van a encontrar.<sup>10</sup> Si bien los computadores eventualmente pueden ser programados para tratar ambigüedades únicas, los humanos siempre deben estar allí para tratar y clasificar

lo impredecible. Con su mejor entendimiento contextual, los humanos a menudo podrían tropezar con conexiones casuales que las máquinas puedan perder.

- **El pensamiento “lento” y la subjetividad son fortalezas, no limitaciones.** La subjetividad humana y el pensamiento “lento” (esto es, conocimiento deliberado, con esfuerzo, analítico), a menudo considerados limitaciones, realmente pueden ser fortalezas que les ayuden a las organizaciones a hacer el mejor uso de la colaboración humano-máquina.<sup>11</sup> Como las máquinas se vuelven cada vez más rápidas, los humanos deben ir más despacio para hacer su mejor trabajo de dos maneras: (1) mediante conectar elementos desconectados para trazar inferencias matizadas, y (2) mediante separar los elementos agregados si están agrupados estadística, pero no lógicamente. Como los humanos se sienten apurados para mantener el ritmo de la tecnología, los incentivos y la cultura corporativos deben evolucionar para fomentar el pensamiento lento

**Como los humanos se sienten apurados para mantener el ritmo de la tecnología, los incentivos y la cultura corporativos deben evolucionar para fomentar el pensamiento lento.**

- **Las firmas inteligentes no solo deben celebrar sino nutrir las capacidades humanas.** La investigación reciente sobre habilidades y capacidades ha identificado calidades humanas perdurables, tales como curiosidad, imaginación, y empatía, que las firmas inteligentes probablemente aprenderán a capitalizar (figura 7).<sup>12</sup> En la figura 8, identificamos cómo esas capacidades pueden y deben pagar en el análisis cualitativo.

FIGURA 7

## El trabajo redefinido se basa en las capacidades humanas en todas las actividades que se necesitan para abordar oportunidades inadvertidas



Fuente: John Hagel, John Seely Brown, and Maggie Wooll, Can we realize untapped opportunity by redefining work?, Deloitte Insights, October 24, 2018.

Con el poder sinérgico de hombre y máquina, la investigación cualitativa puede ser hecha más eficientemente. Mediante dejar que los analistas e investigadores humanos sean lentos y sean “más humanos,” las perspectivas, las recomendaciones,

y el valor derivado de la investigación cualitativa puede exceder lo que se ha logrado. Nosotros valoramos y fomentamos que las firmas acojan sus nuevos compañeros tecnológicos, pero es aparente que para el análisis de datos todavía necesitamos equipo humano por sus capacidades únicas.

FIGURA 8

## Cavando en profundidad: Cómo las capacidades humanas únicas pueden contribuir a la investigación cualitativa



Fuente: Análisis de Deloitte.

Deloitte Insights | [deloitte.com/insights](https://deloitte.com/insights)

## Notas finales

1. Dr. Michela Coppola et al., *Voice of the workforce in Europe: Understanding the expectations of the labour force to keep abreast of demographic and technological change*, Deloitte Insights, November 29, 2018.
2. Jim Guszczka and Jeff Schwartz, "Superminds: How humans and machines can work together," *Deloitte Review* 24, January 28, 2019; Thomas W. Malone, *Superminds: The Surprising Power of People and Computers Thinking Together* (Little, Brown and Company, 2018).
3. Coppola et al., *Voice of the workforce in Europe*.
4. Ranjit Kumar, *Research Methodology: A Step-By-Step Guide for Beginners* (SAGE Publications, 2005), pp.136–137. IEn un mundo ideal de diseño de encuesta, las preguntas de doble cañón, abiertas, tienen que ser evitadas a toda costa, pero en la práctica son bastante comunes. En algunos casos, esto se puede deber al desarrollo sub-óptimo de la pregunta de la encuesta o que la pregunta sea una pregunta mascota heredada o de un stakeholder clave. Sin embargo, algunas veces quienes diseñan encuestas toman una decisión consciente para combinar dos problemas en una pregunta abierta, posiblemente para capturar perspectivas fuera del alcance de las preguntas cuantitativas sin sustantivamente incrementar el número de preguntas, en un esfuerzo para minimizar costos y evitar fatiga de encuesta entre quienes respondan.
5. Fernanda Viégas and Martin Wattenberg, "Timelinstag clouds and the case for vernacular visualization," *ACM Interactions*, July and August 2008.
6. Shelby Temple, "Word clouds are lame," Medium, accessed October 7, 2019.
7. Coppola et al., *Voice of the workforce in Europe*.
8. Vale la pena observar que esos temas podrían tener sentimientos tanto positivos como negativos, tal y como son expresados por quienes respondieron. Por ejemplo, el centro de atención puesto en el entrenamiento puede motivar a algunos empleados, mientras que otros pueden sentirse presionados por la necesidad de mejorar continuamente. En caso de que una sola respuesta expresó sentimientos tanto positivos como negativos, el equipo clasificó las declaraciones como únicamente positivas o negativas con base en el matiz dominante.
9. Ibid.
10. Guszczka and Schwartz, "Superminds"; Malone, *Superminds*.
11. Daniel Kahneman, *Thinking, Fast and Slow* (Farrar, Straus and Giroux, 2011).
12. John Hagel, John Seely Brown, and Maggie Wooll, *Redefine work: The untapped opportunity for expanding value*, Deloitte Insights, October 24, 2018.

## Acerca de los autores

### **Monika Mahto** | [mmahto@deloitte.com](mailto:mmahto@deloitte.com)

Monika Mahto es gerente de investigación en Deloitte Services India Pvt. Ltd., afiliada con el Deloitte Center for Integrated Research. Mahto tiene más de 11 años de experiencia en el desarrollo de investigación en profundidad y liderazgo del pensamiento de alto impacto centrada en innovaciones digitales relacionadas con fabricación aditiva y avanzada, futuro del trabajo, industria 4.0, el internet de las cosas, y otras tecnologías avanzadas. Ha desarrollado estructuras originales cuantitativas y cualitativas mediante el uso de varias metodologías de investigación. En su rol, colabora con otros líderes de pensamiento, ejecutivos de industria, y académicos para entregar perspectivas sobre las implicaciones estratégicas y organizacionales de esas tecnologías. Tiene su sede en Mumbai, India. Conéctese con ella en LinkedIn en <https://www.linkedin.com/in/monika-mahto-4238487/> y en Twitter [@mahtomonica](https://twitter.com/mahtomonica).

### **Susan K. Hogan** | [suhogan@deloitte.com](mailto:suhogan@deloitte.com)

Susan K. Hogan es investigador en Deloitte Services LP y especialista temático del Deloitte's Center for Integrated Research. Ella lidera sus campañas de Future of Work, economía comportamental, y administración. En su rol, Hogan trabaja con múltiples líderes para entregar perspectivas estratégicas alrededor del Future of Work. Su investigación se centra en todas las facetas de la experiencia de la fuerza de trabajo, la naturaleza cambiante del trabajo, comportamiento humano y procesos de decisión a través de industrias. Hogan tiene un BA en mercadeo de la Michigan State University, un MBA en finanzas de Stern (NYU) y un PhD de Wharton (UPenn). Conéctese con ella en LinkedIn en <https://www.linkedin.com/in/susanhogan1/> y en Twitter [@Shogan501](https://twitter.com/Shogan501).

### **Steven W. Hatfield** | [sthatfield@deloitte.com](mailto:sthatfield@deloitte.com)

Steven W. Hatfield es directivo de Deloitte Consulting LLP y sirve como el líder global para el Future of Work de la firma. Tiene más de 20 años de experiencia en asesorar organizaciones globales en problemas de estrategia, innovación, organización, personas, cultura, y cambio. Hatfield ha asesorado líderes de negocio en una multitud de iniciativas que incluyen estrategia de activación, definición del futuro preferido, abordaje de las tendencias de la fuerza de trabajo, implementación de modelos de operación ágiles y con capacidad de operación, y transformación de cultura orientada a crecimiento, innovación, y agilidad. Hatfield tiene experiencia importante en llevar a la vida las tendencias continuas que impactan el futuro del trabajo, de la fuerza de trabajo, y del lugar de trabajo. Es un orador regular y autor sobre el futuro del trabajo, y actualmente está en el equipo de liderazgo de Deloitte que le da forma a la investigación y al diálogo del mercado sobre la fuerza de trabajo del futuro y las tendencias y problemas del lugar de trabajo. Tiene una maestría en cambio social y desarrollo de Johns Hopkins y un MBA de Wharton, y tiene su sede en Boston. Conéctese con él en LinkedIn en <https://www.linkedin.com/in/stevehatfielddeloitte/> y en Twitter [@sthatfield](https://twitter.com/sthatfield).

**Michela Coppola | micoppola@deloitte.de**

Michaela Coppola es gerente de investigación del EMEA Research Centre especializado en identificación, definición del alcance, y desarrollo, del liderazgo del pensamiento internacional. Coppola también lidera la encuesta European CFO, de Deloitte, un estudio semestral que reúne las opiniones de más de 1,600 CFO a través de 20 países. Antes de unirse a Deloitte, Coppola desarrolló liderazgo del pensamiento para Allianz Asset Management. Tiene un PhD en economía y tiene su sede en Munich. Conéctese con ella en LinkedIn en <https://www.linkedin.com/in/mcoppola27/> y en Twitter [@coppola\\_michela](https://twitter.com/coppola_michela).

**Abha Kulkarni | abhakikulkarni@deloitte.com**

Abha Kulkarni es analista senior del Deloitte Center for Integrated Research, Deloitte Services India Pvt. Ltd. Apoya la campaña del Future of Work mediante analizar datos de la fuerza de trabajo a través de industrias y regiones. Su principal centro de atención está en aplicar técnicas de investigación cuantitativa para permitir perspectivas de investigación orientadas por datos. Tiene su sede en Mumbai, India. Conéctese con ella en LinkedIn en <https://www.linkedin.com/in/abha-kulkarni-875b7024/> y en Twitter [@AbhaKulkarn90](https://twitter.com/AbhaKulkarn90).

## Agradecimientos

Los autores desean dar las gracias a **Alok Ranjan, Brenna Sniderman, Carly Ackerman, Erin Robertson, Junko Kaji, Ramani Moses, Mark Cotteleer, Maggie Wool, Mayank Baheti, y Nabila Natarajan** por sus valiosas contribuciones a la investigación y la escritura.

## Contáctenos

*Nuestras perspectivas pueden ayudarle a tomar ventaja del cambio. Si usted está buscando ideas frescas para abordar sus desafíos, debemos hablar.*

### **Steven W. Hatfield**

Principal | Deloitte Consulting LLP  
+1 212 618 4046 | [sthatfield@deloitte.com](mailto:sthatfield@deloitte.com)

Steven W. Hatfield es directivo de Deloitte Consulting y líder de la práctica de Workforce Transformation que sirve a clientes globales.

### **Brenna Sniderman**

Leader | The Deloitte Center for Integrated Research | Deloitte Services LP  
+1 929 251 2690 | [bsniderman@deloitte.com](mailto:bsniderman@deloitte.com)

Brenna Sniderman lidera el Deloitte's Center for Integrated Research.

### **Susan K. Hogan**

Research lead | The Deloitte Center for Integrated Research | Deloitte Services LP  
+1 404 220 1994 | [suhogan@deloitte.com](mailto:suhogan@deloitte.com)

Susan K. Hogan es investigador del Deloitte's Center for Integrated Research.

### **Michela Coppola**

Manager | Deloitte Germany  
+49 89 29036 8099 | [micoppola@deloitte.de](mailto:micoppola@deloitte.de)

Michaela Coppola es gerente de investigación del EMEA Research Centre y también lidera la encuesta Deloitte's European CFO.

# Deloitte.

## Insights

Suscríbase para actualizaciones de Deloitte Insights en [www.deloitte.com/insights](http://www.deloitte.com/insights).

 Siga a @DeloitteInsight

### Colaboradores de Deloitte Insights

**Editorial:** Junko Kaji, Ramani Moses, Nairita Gangopadhyay, Anya George, Blythe Hurley, y Preetha Devan

**Creativo:** Kevin Weier and Molly Woodworth

**Promoción:** Ankana Chakraborty

**Artes:** Jon Reinfurt

### Acerca de Deloitte Insights

Deloitte Insights publica artículos originales, reportes y publicaciones periódicas que proporcionan ideas para negocios, el sector público y ONG. Nuestra meta es aprovechar la investigación y experiencia de nuestra organización de servicios profesionales, y la de coautores en academia y negocios, para avanzar la conversación sobre un espectro amplio de temas de interés para ejecutivos y líderes del gobierno.

Deloitte Insights es una huella de Deloitte Development LLC.

### Acerca de esta publicación

Esta publicación solo contiene información general, y nadie de Deloitte Touche Tohmatsu Limited, sus firmas miembros, o sus afiliados están, por medio de esta publicación, prestando asesoría o servicios de contabilidad, negocios, finanzas, inversión, legal, impuestos, u otros de carácter profesional. Esta publicación no sustituye tales asesoría o servicios profesionales, ni debe ser usada como base para cualquier decisión o acción que pueda afectar sus finanzas o sus negocios. Antes de tomar cualquier decisión o realizar cualquier acción que pueda afectar sus finanzas o sus negocios, usted debe consultar un asesor profesional calificado.

Nadie de Deloitte Touche Tohmatsu Limited, sus firmas miembros, o sus respectivos afiliados serán responsables por cualquier pérdida tenida por cualquier persona que confíe en esta publicación.

### About Deloitte

Deloitte se refiere a uno o más de Deloitte Touche Tohmatsu Limited, una compañía privada del Reino Unido limitada por garantía ("DTTL"), su red de firmas miembros, y sus entidades relacionadas. DTTL y cada una de sus firmas miembros son entidades legalmente separadas e independientes. DTTL (también referida como "Deloitte Global") no presta servicios a clientes. En los Estados Unidos, Deloitte se refiere a una o más de las firmas de los Estados Unidos miembros de DTTL, sus entidades relacionadas que operan usando el nombre "Deloitte" en los Estados Unidos y sus respectivas afiliadas. Ciertos servicios pueden no estar disponibles para atestar clientes según las reglas y regulaciones de la contaduría pública. Para aprender más acerca de nuestra red global de firmas miembros por favor vea [www.deloitte.com/about](http://www.deloitte.com/about).

Copyright © 2020 Deloitte Development LLC. All rights reserved.  
Member of Deloitte Touche Tohmatsu Limited

Documento original: **Looping in your new sidekick. The role of machine learning in qualitative data analysis.** Deloitte Insights, february 2020.

<https://www2.deloitte.com/us/en/insights/focus/technology-and-the-future-of-work/machine-learning-qualitative-data.html>.

Traducción realizada por Samuel A. Mantilla, asesor de investigación contable de Deloitte & Touche Ltda., Colombia.